

Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet50V2 Untuk Mengidentifikasi Penyakit Pneumonia

Muhammad Agil Izzulhaq*, Alamsyah

Program Studi Teknik Informatika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D5 Lt.2, Kampus Sekaran Gunungpati, Semarang 50229
E-mail: agilizzulhaq@students.unnes.ac.id

Diterima 12 Januari 2024

Disetujui 20 Maret 2024

Abstrak

Pneumonia adalah penyakit yang menginfeksi saluran pernapasan, mengganggu fungsi normal tubuh manusia. Virus dan bakteri dikenal sebagai penyebab umum pneumonia. Identifikasi Penyakit Pneumonia dapat menggunakan Convolutional Neural Network (CNN). CNN merupakan arsitektur jaringan saraf tiruan yang efektif untuk analisis gambar, terinspirasi oleh cara otak manusia memproses informasi visual. CNN mampu memahami hierarki fitur dalam gambar, dari garis dan sudut hingga bentuk dan objek kompleks. Penelitian ini bertujuan menggunakan ResNet50V2, sebuah arsitektur CNN populer, untuk mengklasifikasikan gambar x-ray sebagai normal atau menunjukkan tanda-tanda pneumonia, dengan tujuan menciptakan alat diagnostik yang akurat dan efisien. Metode penelitian melibatkan penggunaan dataset gambar x-ray untuk pelatihan, validasi, dan pengujian, dengan menggunakan arsitektur CNN ResNet50V2. Hasil pengujian menunjukkan bahwa ResNet50V2 memiliki akurasi klasifikasi pneumonia sebesar 93,26%. Studi ini memiliki kebaruan dalam mencari alternatif arsitektur CNN untuk klasifikasi pneumonia, dengan fokus pada ResNet50V2.

Kata kunci: Pneumonia, CNN, ResNet50V2

Abstract

Pneumonia is a disease that infects the respiratory tract, disrupting the normal function of the human body. Viruses and bacteria are known as common causes of pneumonia. Identification of Pneumonia can use Convolutional Neural Network (CNN). CNN is an effective artificial neural network architecture for image analysis, inspired by how the human brain processes visual information. CNNs are capable of understanding the hierarchical features in images, from lines and angles to complex shapes and objects. This research aims to use ResNet50V2, a popular CNN architecture, to classify X-ray images as either normal or indicative of pneumonia, with the goal of creating an accurate and efficient diagnostic tool. The research method involves using X-ray image datasets for training, validation, and testing, using the ResNet50V2 CNN architecture. The test results show that ResNet50V2 achieves a pneumonia classification accuracy of 93.26%. This study innovatively explores alternative CNN architectures for pneumonia classification, focusing on ResNet50V2.

Keywords: Pneumonia, CNN, ResNet50V2

How to cite:

Izzulhaq, M. A., & Alamsyah, A. (2024). Penerapan algoritma convolutional neural network arsitektur ResNet50V2. *Indonesian Journal of Mathematics and Natural Sciences*, 47(1), 12-22

PENDAHULUAN

Penyakit akut telah menjadi perhatian selama beberapa tahun terakhir. Peningkatan eksponensial penyakit tersebut mengakibatkan tingginya angka kematian di berbagai negara dan kerugian ekonomi jangka panjang (Leung, 2021). Pneumonia merupakan salah satu penyakit yang menyebabkan infeksi saluran pernapasan yang dapat mengganggu fungsi normal tubuh manusia. Beberapa penyebab pneumonia yang diketahui adalah virus dan bakteri. Faktor penting dalam penyebaran virus dan bakteri ini adalah penurunan kualitas udara. Paru-paru manusia terdiri dari kantung-kantung kecil yang disebut alveolus. Kantung-kantung udara ini bertanggung jawab untuk

menukar gas-gas penting, yaitu oksigen dan karbon dioksida. Ketika seseorang menderita pneumonia, kantung-kantung ini terisi dengan nanah dan cairan, sehingga mengurangi pertukaran gas antara darah dan paru-paru. Pneumonia dapat menyebabkan kesulitan bernapas dan komplikasi lain seperti nyeri dada, batuk, muntah, diare, dan kelelahan (Prakash *et al.*, 2023).

Di Amerika Serikat, lebih dari 1 juta orang dirawat di rumah sakit karena pneumonia setiap tahunnya, dengan hampir setengah juta kematian (Sharma & Guleria, 2022). Selain itu, dilaporkan juga oleh WHO pada tahun 2019 bahwa pneumonia membunuh 14% anak di bawah usia 5 tahun di seluruh dunia. Hal ini memotivasi perluasan model berbasis *deep learning* untuk prediksi pneumonia dini sehingga nyawa manusia yang berharga dapat diselamatkan dengan memberikan pengobatan tepat waktu dan mengurangi peningkatan kematian yang disebabkan oleh pneumonia. Gambar *x-ray* dada (CXR) adalah teknik yang sangat efektif dan mudah diakses untuk mendeteksi pneumonia dan memiliki aplikasi penting dalam studi epidemiologi dan perawatan kesehatan. Identifikasi pneumonia pada gambar CXR adalah tugas yang sulit dan menantang yang membutuhkan kehadiran ahli radiologi profesional. Pneumonia adalah penyakit pernapasan yang berhubungan dengan dada yang diakibatkan oleh penyebaran bakteri, infeksi, dan jamur melalui udara yang dihirup (Singh & Tripathi, 2022). Penyakit ini menyebar ke dada, menyebabkan lebih banyak masalah pernapasan. Pneumonia adalah penyebab utama meningkatnya angka kematian pada anak di bawah usia lima tahun. Cara yang paling efektif untuk mendeteksi pneumonia adalah dengan menggunakan gambar *x-ray*, yang lebih hemat biaya dan lebih ekstensif daripada prosedur diagnostik standar lainnya. Ahli radiologi dengan hati-hati mengidentifikasi dan menganalisis gambar *x-ray* untuk mendeteksi pneumonia, yang merupakan proses yang memakan waktu, dan dapat menyebabkan konflik di antara para ahli radiologi mengenai prediksi penyakit. Oleh karena itu, masalah ini mengarah pada pengembangan metode deteksi pneumonia yang aman untuk digunakan di departemen perawatan kesehatan untuk diagnosis pneumonia secara *real-time* tanpa kesalahan.

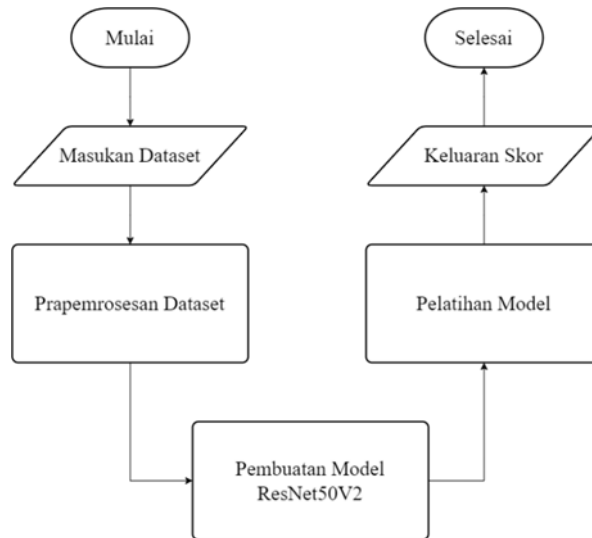
Dalam sistem diagnostik penyakit, *machine learning*, *deep learning*, dan metode statistik merupakan alat yang sangat efisien (Sirazitdinov *et al.*, 2019; Sharma *et al.*, 2021; Alamsyah & Fadila, 2021). Metode-metode ini dapat digunakan untuk menyelesaikan tugas-tugas penglihatan yang sangat canggih di sektor pencitraan kesehatan, seperti klasifikasi penyakit paru-paru, segmentasi paru-paru, dan banyak lagi. Kemajuan terbaru dalam *deep learning* telah membantu mencapai dan bahkan mungkin secara signifikan melebihi kinerja manusia dalam banyak aktivitas. *Deep learning* juga dapat digunakan untuk menentukan hasil pengobatan, seperti studi *chevalier* dan pengobatan kanker. Data berlabel dan algoritma berbasis *deep learning* dikaitkan dengan hasil yang menggembirakan dalam kategorisasi penyakit toraks menggunakan modalitas gambar *x-ray*. *Deep learning* muncul sebagai metode mutakhir (Perdomo *et al.*, 2019), di mana dipelajari fitur-fiturnya sendiri, membuatnya lebih kuat dibandingkan dengan *machine learning* dan dengan demikian menambah keuntungan bagi sistem diagnostik berbantuan komputer. *Deep learning* dimulai dengan beberapa lapisan tersembunyi dan secara bertahap diperluas ke beberapa lapisan CNN yang menghasilkan arsitektur CNN yang mendalam. Arsitektur ini merupakan teknik yang paling banyak digunakan untuk tugas pengenalan pola dan klasifikasi (Puttagunta & Ravi, 2021; Alamsyah *et al.*, 2021).

Arsitektur ResNet50V2 adalah Convolutional Neural Network (CNN) canggih yang telah menunjukkan kinerja luar biasa dalam berbagai tugas visi komputer, termasuk analisis gambar medis. Ini adalah jaringan residual dalam yang menggunakan koneksi residual untuk meningkatkan pelatihan jaringan dalam. Arsitektur ResNet50V2 telah digunakan dalam berbagai aplikasi, seperti pengenalan gambar, deteksi objek, dan segmentasi. Ini juga telah diterapkan dalam analisis gambar medis, termasuk identifikasi penyakit pernapasan dari gambar *x-ray* dada. Performanya yang unggul dalam tugas-tugas ini telah menjadikannya pilihan populer bagi para peneliti dan praktisi di bidang *deep learning*.

Tujuan dari penelitian ini adalah untuk mengembangkan model *deep learning* menggunakan arsitektur ResNet50V2 untuk mengidentifikasi pneumonia secara akurat dari gambar *x-ray* dada. Pengembangan alat identifikasi pneumonia yang akurat dan efisien berpotensi membantu deteksi dini dan pengobatan penyakit yang mengancam jiwa ini, meningkatkan hasil pengobatan dan mengurangi biaya perawatan kesehatan.

METODE

Alur desain metode yang diusulkan digambarkan seperti yang ditunjukkan pada Gambar 1. Setiap langkah pada Gambar 1 dijelaskan pada bagian selanjutnya.



Gambar 1. Flowchart metode yang diusulkan

Masukan Dataset

Dataset diperoleh dari laman *Kaggle* yang memuat gambar-gambar *x-ray* yang telah terorganisir dalam tiga folder terpisah, yaitu *train*, *test*, dan *val*, masing-masing dengan sub folder untuk setiap kategori gambar, baik Pneumonia maupun Normal. Total terdapat 5.863 gambar *x-ray* dalam format JPEG dan terdiri dari dua kategori utama, yaitu Pneumonia dan Normal. Gambar-gambar *x-ray* dada (diperoleh melalui proyeksi anterior posterior) dipilih dari kohort retrospektif pasien anak-anak berusia satu hingga lima tahun yang berobat di Guangzhou Women and Children's Medical Center, Guangzhou. Setiap gambar *x-ray* dada merupakan bagian dari prosedur perawatan klinis rutin bagi pasien-pasien tersebut.

Prapemrosesan Dataset

Langkah selanjutnya setelah dataset dimuat adalah mengambilnya dengan ukuran yang telah ditentukan sebelumnya. Dalam hal ini, data diambil dengan ukuran yang telah diubah menjadi (224, 224) dan dengan ukuran *batch* sebesar 32. Kemudian, dilakukan penggunaan Keras *ImageDataGenerator* untuk memperoleh data *input* asli dan mengaplikasikan transformasi secara acak pada data tersebut, menghasilkan *output* yang hanya berisi data yang baru saja ditransformasikan. Penting untuk dicatat bahwa kelas ini tidak menambahkan data, namun digunakan untuk melakukan augmentasi data dengan tujuan meningkatkan generalisasi model secara keseluruhan. Dalam proses augmentasi data menggunakan *ImageDataGenerator*, berbagai operasi seperti rotasi, translasi, pergeseran, pengubahan skala, dan pembalikan horizontal dilakukan secara acak untuk meningkatkan variasi dan keberagaman data yang digunakan dalam pelatihan model sebagaimana disajikan pada Tabel 1.

Tabel 1. Metode augmentasi yang digunakan dan nilainya

Metode	Nilai
<i>Rescale</i>	1/255
<i>Shear</i>	10
<i>Zoom</i>	0.3
<i>Horizontal Flip</i>	<i>True</i>
<i>Vertical Flip</i>	<i>True</i>
<i>Brightness</i>	[0.5, 2.0]
<i>Width Shift</i>	0.2
<i>Rotation</i>	20
<i>Fill Mode</i>	<i>Nearest</i>

Pembuatan Model ResNet50V2

Convolutional Neural Network (CNN) merupakan salah satu pendekatan dalam ranah *deep learning* yang telah terbukti sangat efektif dalam mengidentifikasi objek dalam citra digital. Dengan kemampuannya yang luar biasa, CNN telah menjadi pilihan utama dalam berbagai aplikasi pengenalan

pola visual, mulai dari pengenalan wajah hingga kendaraan dalam lalu lintas. Metode ini beroperasi menggunakan pendekatan *supervised learning*, di mana model CNN dilatih dengan dataset yang telah diberi label, sehingga mampu mengenali pola-pola kompleks dalam data yang belum pernah dilihat sebelumnya. Arsitektur CNN sendiri terdiri dari beberapa lapisan, termasuk *convolutional layer*, *pooling layer*, dan *fully connected layer*. Lapisan konvolusi adalah inti dari CNN, di mana proses konvolusi dilakukan untuk mengekstrak fitur-fitur penting dari gambar, memungkinkan jaringan untuk belajar pola-pola yang lebih kompleks. Dengan menggunakan operasi konvolusi, CNN mampu menghasilkan representasi fitur yang lebih abstrak dan bermanfaat, yang kemudian digunakan untuk mengambil keputusan atau membuat prediksi. Dalam operasi konvolusi, filter bergerak di atas citra dengan langkah-langkah tertentu, mengekstrak informasi lokal dari setiap wilayah citra, yang kemudian digunakan untuk pembuatan fitur-fitur yang lebih tinggi. Operasi konvolusi dapat dituliskan pada Persamaan (1).

$$s(t)=(x*w)(t) \quad (1)$$

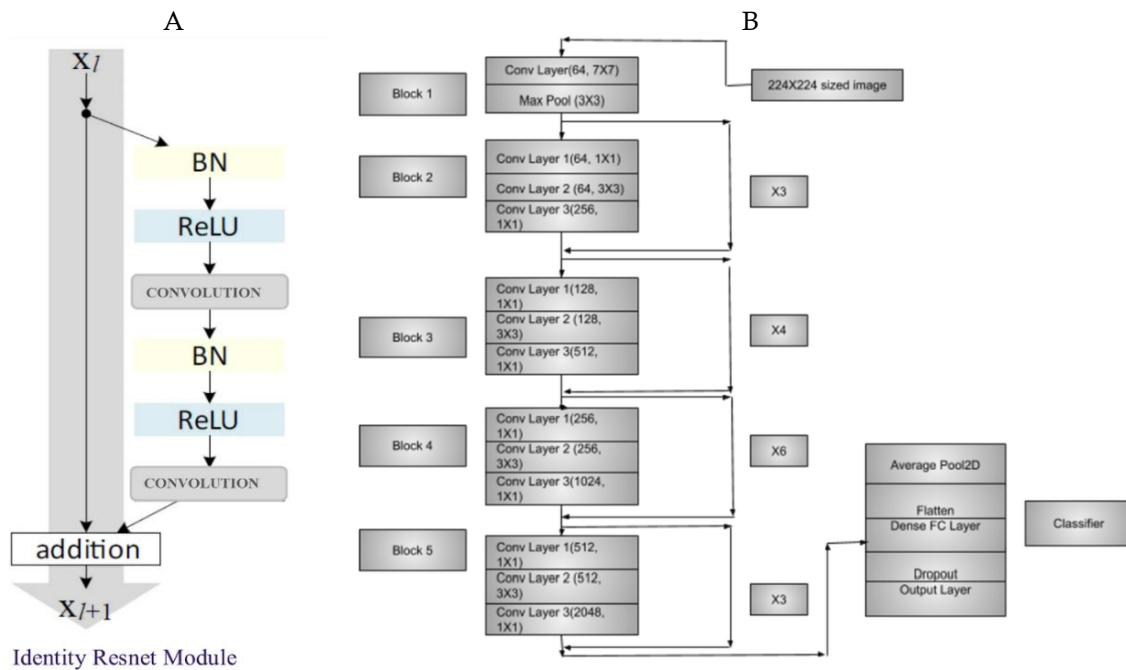
Dengan:

x adalah sinyal masukan atau peta fitur ke dalam lapisan konvolusional di CNN. Dalam kasus gambar, x akan menjadi matriks 2D yang mewakili nilai piksel.

w adalah kernel atau filter konvolusional.

Ini adalah matriks yang lebih kecil dengan dimensi spasial yang lebih kecil daripada x . Tujuan kernel adalah untuk mengekstraksi fitur dari masukan dengan mengkonvolusikannya dengan sinyal masukan. t adalah indeks waktu atau spasial dari sinyal keluaran s .

ResNet50V2 adalah jaringan konvolusi kontemporer yang mengatasi masalah gradien yang menghilang atau meledak menggunakan "blok residual" dalam arsitektur. Dalam jaringan residual sebagaimana disajikan pada Gambar 2, beberapa blok residual ditumpuk satu demi satu. Setiap blok residual dibentuk dari koneksi jalan pintas yang melewati satu atau lebih lapisan. Resnet50V2 menggunakan pra-aktivasi lapisan berat (Das *et al.*, 2021).



Gambar 2. A. Blok residual, B. Arsitektur ResNet50V2 (Das *et al.*, 2021)

Rincian proses pembuatan modelnya adalah sebagai berikut:

1. Membuat model dasar ResNet50V2:
 - a. Langkah pertama adalah membuat sebuah *instance* dari model ResNet50V2 dari modul TensorFlow Keras *Applications*.
 - b. Model tersebut diinisialisasi dengan bobot pra-terlatih dari dataset '*imagenet*'.

- c. Parameter *include_top* diatur menjadi *False* untuk menghilangkan lapisan *fully connected* terakhir dari model.
 - d. Parameter *input_shape* diatur menjadi (224, 224, 3), menentukan dimensi yang diharapkan dari gambar *input*.
2. Membekukan lapisan-lapisan pada model dasar:
 - a. Sebuah perulangan akan melalui setiap lapisan dalam *resnet* model *layers*.
 - b. Atribut *trainable* dari setiap lapisan diatur menjadi *False*, yang membekukan lapisan tersebut dan mencegah pembaharuan bobotnya saat pelatihan.
3. Menambahkan lapisan kustom di atas model dasar:
 - a. Keluaran dari model ResNet50V2 ditugaskan ke variabel *x*.
 - b. Lapisan *Global Average Pooling 2D* ditambahkan ke *x* untuk mengurangi dimensi spasial dari keluaran dan mendapatkan vektor fitur dengan panjang tetap.
 - c. Lapisan *Dense* dengan 128 unit dan fungsi aktivasi *relu* ditambahkan untuk memproses fitur lebih lanjut.
 - d. Lapisan *output* terakhir adalah lapisan *Dense* dengan 1 unit dan fungsi aktivasi *sigmoid*, yang menghasilkan prediksi biner.
4. Membuat model:

Kelas TensorFlow Keras Model digunakan untuk membuat sebuah model baru dengan ResNet model *input* sebagai *input* dan *predictions* sebagai *output*.
5. Mengkompilasi model:
 - a. Model tersebut dikompilasi menggunakan metode *compile*.
 - b. Fungsi kerugian diatur menjadi *binary_crossentropy*, yang cocok untuk tugas klasifikasi biner.
 - c. *Optimizer* *adam* digunakan untuk optimasi gradien turun.
 - d. Metrik *accuracy* ditentukan untuk mengevaluasi performa model selama pelatihan.
6. Mengembalikan model yang telah dikompilasi:

ResNet model dikembalikan sebagai hasil dari fungsi *create_model*.

Setelah mendefinisikan fungsi *create_model*, kode tersebut menciptakan sebuah *instance* dari model dengan memanggil *create_model* dan menetapkan hasilnya ke variabel *res_model*. Langkah selanjutnya adalah menampilkan ringkasan arsitektur model menggunakan metode *summary*. Selain itu, kode tersebut menghasilkan representasi visual dari struktur model. Terakhir, gambar yang dihasilkan dipresentasikan menggunakan fungsi *display* dari modul *Image*. Model yang dibuat adalah model klasifikasi kustom yang dibangun di atas model dasar ResNet50V2. Model ini memiliki kemampuan untuk memuat bobot *pre-trained* dan melakukan penyesuaian lebih lanjut untuk tugas spesifik yang diinginkan.

Pelatihan Model

Model *machine learning* dilatih dan divalidasi menggunakan dataset pelatihan dan validasi. Proses pelatihan dilakukan selama 30 *epoch* dengan ukuran *batch* 32 dan langkah per *epoch* 100. Setelah pelatihan selesai, kinerja model disimpan dalam objek riwayat. Objek riwayat tersebut mengandung nilai akurasi dan *loss* dari model untuk setiap *epoch* selama proses pelatihan. Selanjutnya, performa model divisualisasikan menggunakan *library matplotlib*. Plot pertama menampilkan akurasi dari data pelatihan dan validasi untuk setiap *epoch*, sementara plot kedua menampilkan *loss* dari data pelatihan dan validasi untuk setiap *epoch*. Visualisasi ini berguna untuk memonitor performa model dan mengestimasi berapa lama proses pelatihan akan mencapai konvergensi.

Keluaran Skor

Performa model yang telah dilatih dievaluasi menggunakan dataset latih dan uji. Evaluasi dilakukan dengan memanggil fungsi *evaluate* pada objek model yang telah dilatih. Evaluasi pada dataset latih dilakukan pada baris pertama, sementara evaluasi pada dataset uji dilakukan pada baris kedua. Nilai *loss* dan akurasi model pada kedua dataset tersebut kemudian dicetak menggunakan fungsi *print*. Dengan melakukan evaluasi performa model pada kedua dataset, kita dapat menilai performa model secara keseluruhan dan menentukan kemampuan generalisasinya pada data yang tidak terlihat sebelumnya. Hasil dari evaluasi tersebut dapat digunakan sebagai referensi untuk menentukan apakah

model sudah cukup baik atau perlu dilakukan penyempurnaan lebih lanjut atau perbaikan pada arsitektur model.

Penelitian ini dilakukan di Laboratorium Kultur Jaringan, FMIPA, Universitas Negeri Semarang. Eksplan tanaman yang digunakan adalah bagian pelepah kuncup umbi bawang merah varietas bima Brebes. Variabel bebas meliputi konsentrasi BAP dan konsentrasi pikloram yang masing-masing terdiri dari 0 ppm, 1 ppm, 2 ppm, 3 ppm. Variabel terikat penelitian meliputi waktu muncul kalus, persentase tumbuh kalus, dan morfologi kalus (warna dan tekstur). Variabel kontrol berupa media Murashige and Skoog (MS), suhu ruangan $\pm 20-25^{\circ}\text{C}$, kelembapan 52-58%, di bawah pencahayaan (lampu LED) sebesar 2.000 lux yang dipertahankan selama 12 jam dalam sehari. Penelitian ini dirancang dengan rancangan acak lengkap (RAL) pola faktorial dengan dua faktor. Faktor pertama adalah konsentrasi BAP dan faktor kedua adalah konsentrasi pikloram. Masing-masing terdiri dari 4 taraf sehingga diperoleh 16 kombinasi perlakuan. Unit penelitian adalah 16 perlakuan dengan lima kali ulangan sehingga terdiri dari 80 unit.

Pembuatan dan Sterilisasi Media

Komposisi media perlakuan terdiri atas media MS, gula, inositol, pematat (agar) dan ZPT BAP dan pikloram. Media diatur pada pH seimbang yaitu 5.8 - 6,0. Sterilisasi media dilakukan dengan autoklaf pada suhu 121°C dan tekanan 1.5 atm selama 20 menit.

Sterilisasi Eksplan

Eksplan umbi bawang merah dicuci di bawah air mengalir selama 30 menit, dilanjutkan sterilisasi dengan zat antiseptik selama 50 menit, perendaman eksplan dengan fungisida 0,1 g/L dan bakterisida 0,1 g/L yang sudah dilarutkan masing-masing 50 menit. Sterilisasi dalam *laminar air flow*, terdiri dari perendaman eksplan dalam natrium hipoklorit 70%, 30% dan 100 % masing-masing selama 10 menit. Setiap tahapan yang dilakukan, eksplan umbi dibilas dengan akuades. Setiap pembilasan dilakukan selama 2 menit untuk memastikan eksplan bersih dari bahan aktif sterilan.

Penanaman dan Inkubasi

Eksplan umbi diambil dengan memotong setiap permukaannya (seperti dikupas) untuk membuang bagian mati akibat proses sterilisasi. Pengupasan dilakukan sampai bagian terdalam. Bagian tersebut ditanam pada media perlakuan, setiap botol diisi 1 potongan eksplan. Hasil penanaman tersebut kemudian diinkubasi selama 45 hari pada ruang kultur dengan suhu $\pm 20-25^{\circ}\text{C}$, kelembapan 52-58%, di bawah pencahayaan (lampu LED) sebesar 2.000 lux yang dipertahankan selama 12 jam dalam sehari.

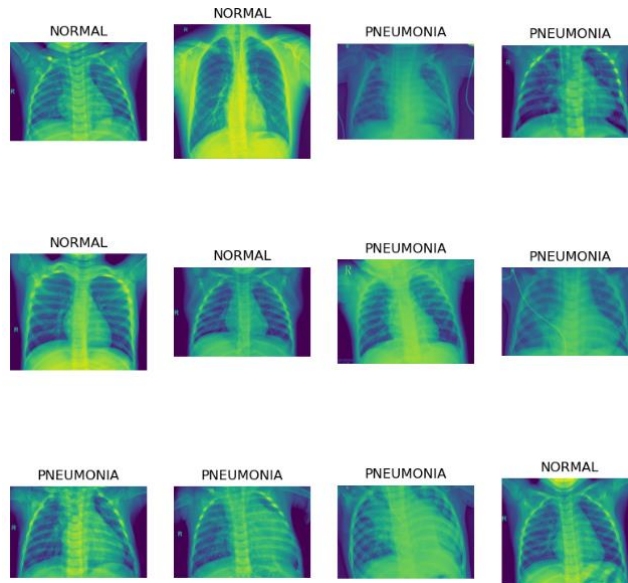
Pengamatan

Indikator pengamatan terdiri dari waktu muncul kalus, persentase tumbuh kalus, dan morfologi kalus. Data waktu muncul kalus dan persentase tumbuh kalus dianalisis dengan uji Kruskal-Wallis pada signifikansi 0,05 menggunakan perangkat SPSS ver. 26 dan jika terdapat perbedaan dilakukan uji lanjut Dunn. Data morfologi kalus yang terdiri dari tekstur dan warna kalus dianalisis secara deskriptif.

HASIL DAN PEMBAHASAN

Identifikasi Gambar Sampel

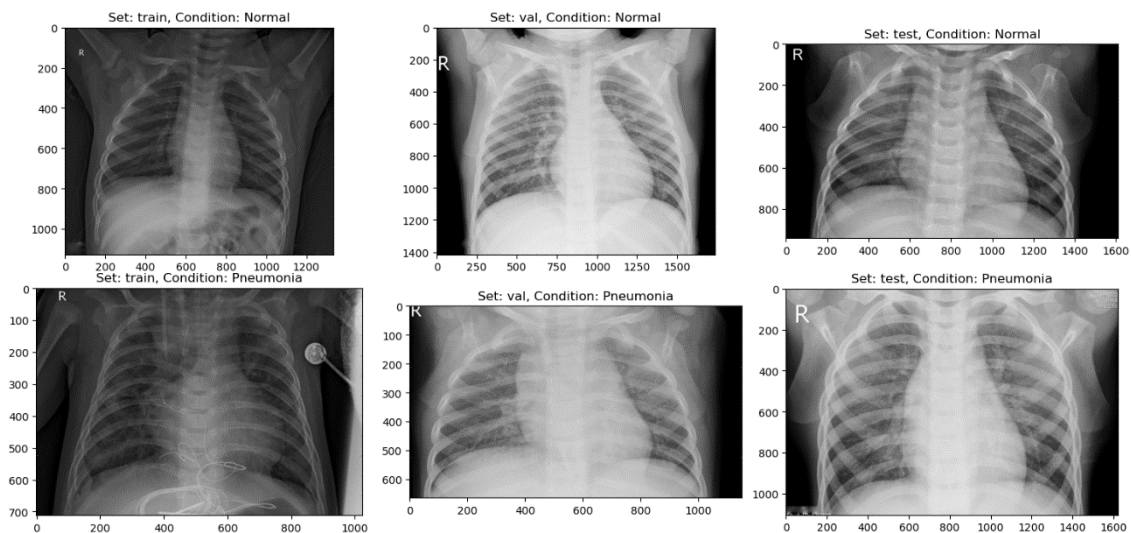
Pada Gambar 3 menampilkan 12 gambar secara visual yang dipilih secara acak dari dua kelas yang berbeda dalam kisi 3x4 merupakan langkah yang penting dalam eksplorasi data serta visualisasi awal dalam proyek *machine learning* atau visi komputer. Tindakan ini memungkinkan kita untuk secara langsung melihat representasi dari kedua kelas yang ada dalam dataset. Dengan melakukannya, kita dapat menilai kualitas representasi data dari masing-masing kelas dan memperoleh pemahaman visual tentang perbedaan karakteristik antara kelas-kelas tersebut. Hasil visualisasi ini juga menjadi landasan untuk pengambilan keputusan lebih lanjut terkait dengan pemrosesan data yang akan dilakukan. Dengan demikian, proses ini membantu dalam menetapkan strategi pemrosesan data yang tepat sebelum melakukan tahap analisis lebih lanjut.



Gambar 3. Identifikasi gambar sampel dari dua kelas yang berbeda

Representasi Dataset

Gambar 4 menampilkan contoh gambar dari tiga set yang berbeda (latih, val, dan uji) dari dataset *x-ray* dada pneumonia dalam format *subplot* 2x3 adalah langkah penting dalam pra-pemrosesan data sebelum melatih model. Pertama-tama, program ini dimulai dengan mendefinisikan jalur ke folder dataset dan membuat kisi *subplot* 2x3 untuk menampilkan gambar. Selanjutnya, melalui proses iterasi, program menampilkan gambar pertama dari setiap set dan kelas (normal dan pneumonia), memberikan judul yang mencerminkan set dan kondisinya. Fungsi ini memberikan gambaran visual yang jelas tentang representasi kedua kelas dalam setiap set dataset, memungkinkan analisis awal terhadap karakteristik dataset, serta memastikan keberagaman data sebelum diolah lebih lanjut. Dengan memahami distribusi dan kualitas dataset sebelumnya, dapat dihasilkan model yang lebih andal dan akurat dalam pengenalan penyakit berdasarkan gambar *x-ray* dada.

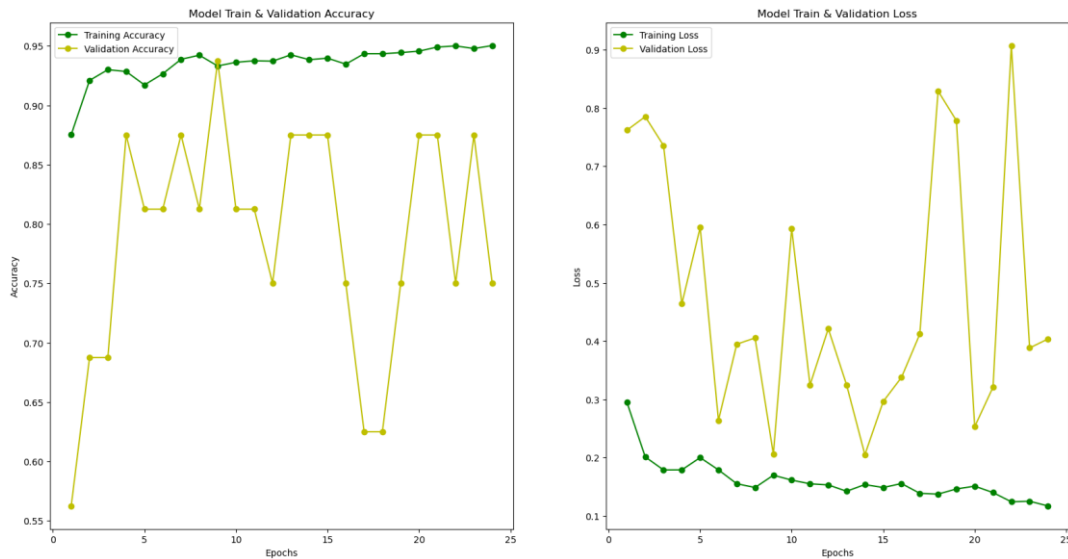


Gambar 4. Representasi dataset

Artefak Pelatihan

Artefak pelatihan sebagaimana disajikan pada Gambar 5, dalam konteks ini merujuk pada metrik utama yang digunakan untuk mengevaluasi kinerja model selama proses pelatihan, yaitu akurasi dan kehilangan (*loss*) pada set pelatihan dan validasi sepanjang jumlah *epoch* tertentu. Fungsi ini memiliki tujuan untuk menyajikan visualisasi yang komprehensif terhadap kedua metrik tersebut dalam

bentuk gambar dengan ukuran 20x10 piksel, terbagi menjadi dua *subplot*: satu untuk memplot akurasi pelatihan dan validasi, dan *subplot* lainnya untuk memplot kehilangan pada kedua set tersebut. Dengan menggunakan riwayat pelatihan yang disimpan dalam objek '*history*', fungsi ini mengekstrak informasi tentang akurasi dan kehilangan dari setiap *epoch*. Kemudian, dengan menggunakan warna dan penanda yang berbeda untuk setiap baris, fungsi ini memplot kedua metrik tersebut terhadap jumlah *epoch*. Dengan judul yang jelas, legenda yang informatif, dan label sumbu yang tepat untuk kedua *subplot*, visualisasi ini menjadi alat yang berguna untuk mengevaluasi kinerja model, mendeteksi *overfitting* atau *underfitting*, serta membuat keputusan yang tepat terkait dengan strategi pelatihan selanjutnya.



Gambar 6. Artefak pelatihan

Evaluasi Model

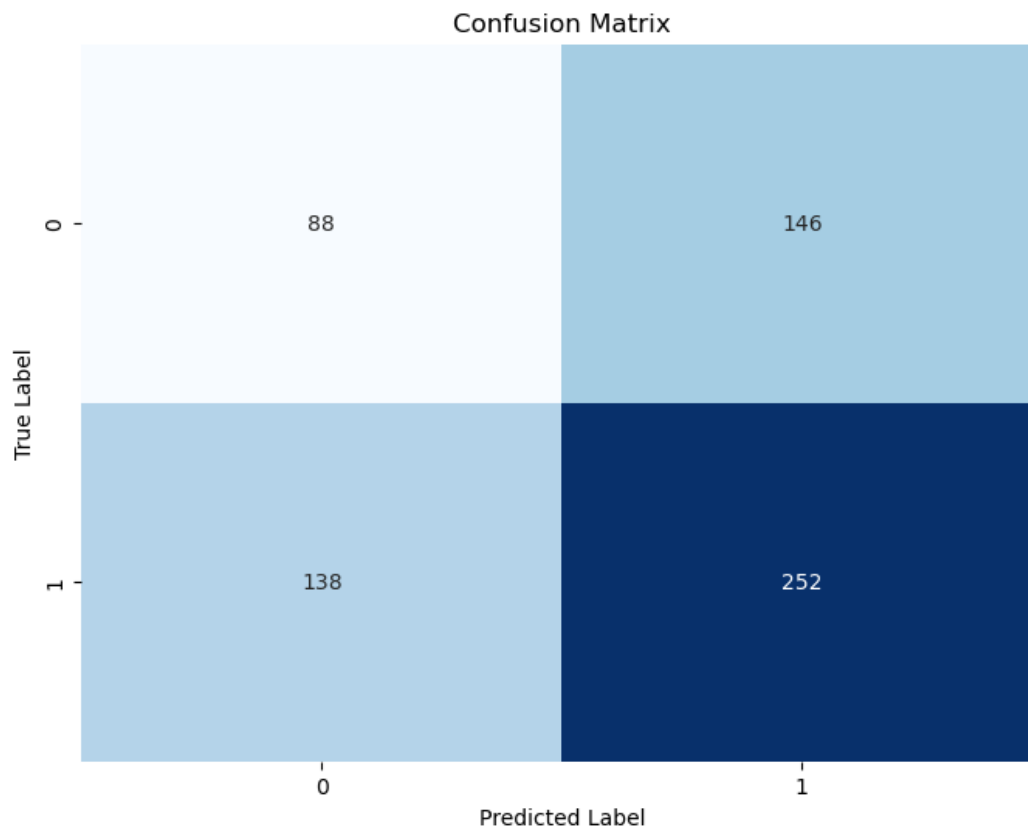
Untuk mengevaluasi performa model pada dataset latih dan uji setelah proses pelatihan, sebuah fungsi '*evaluate*' dikembangkan. Fungsi ini memerlukan dataset sebagai argumen dan melakukan perhitungan akurasi model pada dataset yang diberikan. Pertama, fungsi tersebut melakukan evaluasi model pada dataset latih dan menetapkan hasilnya ke dalam variabel '*score*'. Setelah itu, hasil akurasi pada dataset latih dicetak. Selanjutnya, model dievaluasi pada dataset uji dan hasilnya disimpan dalam variabel '*score*'. Hasil akhir akurasi pada dataset uji dicetak sebagaimana tercantum pada Tabel 2. Tabel 3 menyajikan klasifikasi kategori normal, pneumonia serta *Confusion Matrix* pada Gambar 6. Melalui proses ini, dapat diperoleh pemahaman yang jelas tentang kinerja model pada kedua dataset, serta mengidentifikasi kemungkinan masalah *overfitting* atau *underfitting* yang terjadi selama pelatihan. Dengan demikian, kode ini memberikan gambaran yang penting untuk mengoptimalkan model dan meningkatkan keakuratannya.

Tabel 2. Evaluasi model pada pelatihan dan pengujian

	Akurasi (%)	Hilang (%)
Pelatihan	94.63	12.06
Pengujian	93.26	19.83

Tabel 3. *Classification Reports*

	Presisi	Recall	Skor F1	Support
Normal	0.39	0.38	0.38	234
Pneumonia	0.63	0.65	0.64	390



Gambar 6. *Confusion Matrix* dengan 0 sebagai normal dan 1 sebagai pneumonia

SIMPULAN

Melalui penggunaan arsitektur ResNet50V2 dan teknik prapemrosesan yang disertakan dalam penelitian ini, diperoleh hasil dengan akurasi mencapai 93,26% untuk identifikasi pneumonia dari gambar x-ray dada. Temuan dari penelitian ini menegaskan bahwa pendekatan berbasis deep learning merupakan alternatif yang sangat potensial untuk pengembangan model yang akurat dan dapat diandalkan dalam mendeteksi pneumonia dari citra rontgen dada. Dengan adanya perkembangan dataset yang semakin luas dan kemajuan dalam arsitektur serta teknik deep learning, kita dapat mengantisipasi munculnya model-model yang lebih canggih dan efektif di masa depan. Tak hanya memberikan kontribusi bagi para profesional medis dalam meningkatkan akurasi dan efisiensi dalam mendiagnosis pneumonia, tetapi juga membuka pintu bagi deteksi dini dan penanganan penyakit yang lebih baik, memberikan hasil yang lebih baik bagi pasien. Selain itu, pengembangan model-model ini juga dapat membuka jalan bagi penerapan pendekatan berbasis deep learning dalam berbagai tugas pencitraan medis lainnya, yang akan membawa kemajuan besar dalam sektor perawatan kesehatan secara keseluruhan.

DAFTAR PUSTAKA

- Alamsyah, A., & Fadila, T. 2022. Increased accuracy of prediction hepatitis disease using the application of principal component analysis on a support vector machine. *Journal of Physics: Conference Series*, 1968 012016 <https://doi.org/10.1088/1742-6596/1968/1/012016>
- Alamsyah, A., Prasetyo, B., Hakim, M., & Pradana, F. (2021). Prediction of COVID-19 using recurrent neural network model. *Scientific Journal of Informatics*, 8(1), 98-103. <https://doi.org/10.15294/sji.v8i1.30070>.
- Prakash, J. A., Asswin, C., Ravi, V., Sowmya, V., & Soman, K. (2023). Pediatric pneumonia diagnosis using stacked ensemble learning on multi-model deep CNN architectures. *Multimedia Tools and Applications*, 82(14), 21311-21351. <https://doi.org/10.1007/s11042-022-13844-6>
- Das, A. K., Ghosh, S., Thunder, S., Dutta, R., Agarwal, S., & Chakrabarti, A. (2021). Automatic COVID-19 detection from X-ray images using ensemble learning with convolutional neural

- network. *Pattern Analysis and Applications*, 24(3), 1111–1124. <https://doi.org/10.1007/s10044-021-00970-4>
- El Asnaoui, K., Chawki, Y., & Idri, A. (2021). Automated methods for detection and classification pneumonia based on x-ray images using deep learning. In: Maleh, Y., Baddi, Y., Alazab, M., Tawalbeh, L., Romdhani, I. (eds) *Artificial Intelligence and Blockchain for Future Cybersecurity Applications. Studies in Big Data*, vol 90. Springer, Cham. https://doi.org/10.1007/978-3-030-74575-2_14.
- Habib, N., Hasan, M. M., Reza, M. M., & Rahman, M. M. (2020). Ensemble of CheXNet and VGG-19 feature extractor with random forest classifier for pediatric pneumonia detection. *SN Computer Science*, 1(6), 1-9. <https://doi.org/10.1007/s42979-020-00373-y>
- Habib, N., Hasan, Md. M., & Rahman, M. M. (2020). Fusion of deep convolutional neural network with pca and logistic regression for diagnosis of pediatric pneumonia on chest X-Rays. *Network Biology*, 10(3), 62-76. <https://api.semanticscholar.org/CorpusID:221373678>
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. (2020). Efficient pneumonia detection in chest X-ray images using deep transfer learning. *Diagnostics*, 10(6), 1-23. <https://doi.org/10.3390/diagnostics10060417>
- Leung, N. H. L. (2021). Transmissibility and transmission of respiratory viruses. *Nature Reviews Microbiology*, 19(8), 528-545. <https://doi.org/10.1038/s41579-021-00535-6>
- Nahid, A. Al, Sikder, N., Bairagi, A. K., Razzaque, M. A., Masud, M., Kouzani, A. Z., & Mahmud, M. A. P. (2020). A novel method to identify pneumonia through analyzing chest radiographs employing a multichannel convolutional neural network. *Sensors (Switzerland)*, 20(12), 1-18. <https://doi.org/10.3390/s20123482>
- Perdomo, O., Rios, H., Rodríguez, F. J., Otálora, S., Meriaudeau, F., Müller, H., & González, F. A. (2019). Classification of diabetes-related retinal diseases using a deep learning approach in optical coherence tomography. *Computer Methods and Programs in Biomedicine*, 178, 181-189. <https://doi.org/10.1016/j.cmpb.2019.06.016>
- Puttagunta, M., & Ravi, S. (2021). Medical image analysis based on deep learning approach. *Multimedia Tools and Applications*, 80(16), 24365-24398. <https://doi.org/10.1007/s11042-021-10707-4>
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G., & Antani, S. (2018). Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences (Switzerland)*, 8(10). <https://doi.org/10.3390/app8101715>
- Rubini, C., Pavithra, N., Engineering, E. E., Kumarasamy, M., & Image, A. I. (2019). Contrast Enhancement of MRI Images using AHE and CLAHE Techniques. *International Journal of Innovative Technology and Exploring Engineering*, 9(2), 2442-2445. <https://doi.org/10.35940/ijitee.B7017.129219>
- Sharma, A., Guleria, K., & Goyal, N. (2021). Prediction of diabetes disease using machine learning model BT. *International Conference on Communication, Computing and Electronics Systems* (V. Bindhu, J. M. R. S. Tavares, A.-A. A. Boulogeorgos, & C. Vuppapapati, Eds.; pp. 683–692). Springer Singapore.
- Sharma, S., & Guleria, K. (2022). A Deep learning based model for the detection of pneumonia from chest X-Ray images using VGG-16 and neural networks. *Procedia Computer Science*, 218, 357-366. <https://doi.org/10.1016/j.procs.2023.01.018>
- Siddiqi, R. (2019). Automated Pneumonia diagnosis using a customized sequential convolutional neural network. *Proceedings of the 2019 3rd International Conference on Deep Learning Technologies*, 64–70. <https://doi.org/10.1145/3342999.3343001>
- Siddiqi, R. (2020). Efficient pediatric pneumonia diagnosis using depthwise separable convolutions. *SN Computer Science*, 1(6), 343. <https://doi.org/10.1007/s42979-020-00361-2>
- Singh, S., & Tripathi, B. K. (2022). Pneumonia classification using quaternion deep learning. *Multimedia Tools and Applications*, 81(2), 1743–1764. <https://doi.org/10.1007/s11042-021-11409-7>
- Sirazitdinov, I., Kholiavchenko, M., Mustafaev, T., Yixuan, Y., Kuleev, R., & Ibragimov, B. (2019). Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database. *Computers and Electrical Engineering*, 78, 388–399. <https://doi.org/10.1016/j.compeleceng.2019.08.004>
- Venu, S. K. (2021). An ensemble-based approach by fine-tuning the deep transfer learning models to classify pneumonia from chest X-ray images. *ICAART 2021 - Proceedings of the 13th International*

- Conference on Agents and Artificial Intelligence*, 2, 390–401.
<https://doi.org/10.5220/0010377403900401>
- Wu, H., Xie, P., Zhang, H., Li, D., & Cheng, M. (2020). Predict pneumonia with chest X-ray images based on convolutional deep neural learning networks. *Journal of Intelligent & Fuzzy Systems*, 39, 2893-2907. <https://doi.org/10.3233/JIFS-191438>
- Yu, X., Wang, S. H., & Zhang, Y. D. (2021). CGNet: A graph-knowledge embedded convolutional neural network for detection of pneumonia. *Information Processing and Management*, 58(1), 102411. <https://doi.org/10.1016/j.ipm.2020.102411>